

MESTRADO
ECONOMETRIA APLICADA E PREVISÃO

TRABALHO FINAL DE MESTRADO
DISSERTAÇÃO

**PREVISÕES PARA O PIB DE MACAU: UMA
ABORDAGEM ECONOMETRICA**

PEDRO MANUEL TIRAPICOS BRANQUINHO

OUTUBRO-2018

MESTRADO EM ECONOMETRIA APLICADA E PREVISÃO

TRABALHO FINAL DE MESTRADO DISSERTAÇÃO

**PREVISÕES PARA O PIB DE MACAU: UMA
ABORDAGEM ECONOMETRICA**

PEDRO MANUEL TIRAPICOS BRANQUINHO

ORIENTAÇÃO:

PROFESSOR DOUTOR NUNO RICARDO MARTINS SOBREIRA

OUTUBRO - 2018

Resumo

Face ao crescente aumento de incerteza no que diz respeito à economia, aumenta também a necessidade de possuir o conhecimento e as ferramentas que possibilitem tomar decisões de forma fundamentada relativamente ao futuro. Uma abordagem econométrica permite modelar e projetar as variáveis de interesse para o investigador ou instituição. A variável do Produto Interno Bruto é uma das variáveis económicas mais seguidas, existindo um esforço para a prever com fiabilidade.

Devido ao forte crescimento da Região Administrativa Especial de Macau e as suas ligações históricas com Portugal, Macau abre um conjunto de possibilidades de investimento e negócio por parte de Portugal e empresas portuguesas.

Este trabalho incide sobre a previsão do PIB de Macau através de uma abordagem econométrica. Inicialmente será realizado uma análise acerca da estacionaridade e da existência de relação de cointegração das variáveis utilizadas.

Posteriormente, é efetuado a modelação através de diferentes métodos, os quais serão comparados, a fim de compreender qual mostra o melhor desempenho a nível de previsão. Esta comparação é realizada com diferentes horizontes de previsão e diferentes critérios, tais como o erro quadrático médio e o erro absoluto médio, recorrendo-se ainda ao teste de Diebold-Mariano com o intuito de compreender se os erros de previsão entre modelos são significativos. Os resultados apontaram para um desempenho superior do modelo ADL. Relativamente à previsão para o período desde o segundo trimestre de 2018 até ao primeiro trimestre de 2019, os modelos com exceção do modelo ARIMA, apontam para um abrandamento significativo da economia.

Palavras-chave: PIB de Macau, comparação, VEC, ARIMA, ADL

Abstract

In view of the increasing uncertainty regarding the economy, there is a growing need to possess the knowledge and tools to make informed decisions about the future. An econometric approach allows the modelling and prediction of the variables of interest to the researcher or institution. The Gross Domestic Product variable is one of the economic variables most frequently followed, and there is an effort to forecast it reliably.

Due to the strong growth of the Macao Special Administrative Region and its historical links with Portugal, Macao opens a range of investment and business possibilities for Portugal and portuguese companies.

This work focuses on forecasting Macao's GDP through an econometric approach. Initially, an analysis will be made on the stationarity and existence of a cointegration relation between the variables used.

Afterwards, the modeling is done through different methods, which will be compared in order to understand which shows the best performance at the forecasting. This comparison is carried out with different prediction horizons and different criteria, such as the mean square error and the mean absolute error, while also using the Diebold-Mariano test in order to understand if the prediction errors between models are significant. The results pointed to a superior performance of the ADL model. Regarding the forecast for the horizon ranging from the second quarter of 2018 to the first quarter of 2019, all models with the exception of the ARIMA model point to a significant slowdown in economic activity.

Keywords: Macao's GDP, VEC, ARIMA, ADL, comparison

Agradecimentos

Em primeiro lugar, queria proferir umas palavras especiais de agradecimento ao Professor Nuno Sobreira por todo o apoio, disponibilidade e sugestões de aperfeiçoamento com o qual não seria possível realizar este trabalho.

Agradeço também a todos os professores do mestrado de Econometria Aplicada e Previsão, pelo acompanhamento e suporte ao longo de todo o mestrado.

Sublinho o apoio indispensável da minha família em especial dos meus pais e irmã, cunhado e sobrinha.

Por último, um especial agradecimento à minha namorada, Ana Luzia, que me apoiou incondicionalmente durante todo o meu percurso e sem o qual não teria alcançado o que alcancei até hoje.

ÍNDICE

1.	INTRODUÇÃO	1
2.	REVISÃO BIBLIOGRÁFICA	4
3.	ANÁLISE DESCRITIVA DOS DADOS	6
4.	METODOLOGIA	7
4.1.	Teste de Raiz Unitária	7
4.2.	Teste de Cointegração	11
5.	MODELOS	16
5.1.	VEC	16
5.2.	ADL	17
5.3.	Autoregressive Integrated Moving Average (ARIMA)	20
5.4.	Metodologia Holt-Winters	23
6.	RESULTADOS EMPÍRICOS	24
6.1.	Amostra de Previsão	24
6.2.	Metodologia de Previsão	25
6.3.	Metodologia de Comparação	25
6.4.	Comparação de resultados	27
6.5.	Previsão	29
7.	CONCLUSÃO	30
8.	BIBLIOGRAFIA	33
	ANEXO A – FIGURAS	35
	ANEXO B – TABELAS	39

Índice de Figuras

Figura 1 - Gráfico do PIB de Macau, receitas do jogo e vendas a retalho	35
Figura 2 - Gráfico do PIB de Macau e despesas médias por visitante	35
Figura 3 - Gráfico do PIB de Macau (GDPMO) às primeiras diferenças	36
Figura 4 - Gráfico das receitas de jogo (REVGAME) às primeiras diferenças	36
Figura 5 - Gráfico das vendas a retalho (RETSALE) às primeiras diferenças	37
Figura 6 - Gráfico das despesas médias por visitante (SPEVIS) às primeiras diferenças	37
Figura 7 – FAC e FACP da variável DLGDPMO	38
Figura 8 - Previsões para o PIB de Macau com os diferentes modelos em crescimento homólogo	38

Índice de Quadros

Quadro 1 - Resultados dos critérios de comparação para o período 2014-2018	27
-----------------------------------------------------------------------------------	----

Índice de Tabelas

Tabela A - Resultados dos diferentes testes de raiz unitária	39
Tabela B - Critérios de seleção dos desfasamentos do modelo VAR	39
Tabela C - Valores-p dos testes LM de autocorrelação	39
Tabela D – Valores-p do teste de Jarque-Bera do modelo VAR(4)	40
Tabela E – Valores-p do teste do valor próprio máximo de Johansen	40
Tabela F - Valores-p do teste do traço de Johansen	40
Tabela G – Valor-p do teste do traço de Johansen com quebras de estrutura	41
Tabela H - Valores-p do teste de Wald/ Causalidade de Granger	41
Tabela I - Output da estimação do modelo ADL após procedimento GTS	42
Tabela J - Resultados dos critérios de comparação para o período 2015-2018	42
Tabela K - Resultados dos critérios de comparação para o período 2016-2018	43
Tabela L - Resultados dos critérios de comparação para o período 2017-2018	43
Tabela M - Resultados do teste Diebold-Mariano com previsões dinâmicas	43
Tabela N - Resultados do teste Diebold-Mariano com previsões estáticas	44
Tabela O - Previsões em valor absoluto para a variável do PIB	44
Tabela P - Previsões em variação homóloga para a variável do PIB	45

Glossário

ADL	<i>Autoregressive with Dependent Lags</i>	EAM	Erro Absoluto Médio
ADF	<i>Augmented Dickey Fuller</i>	MAPE	Erro Absoluto Percentual Médio
ARIMA	<i>Autoregressive Integrated Moving Average</i>	PIB	Produto Interno Bruto
DF	Dickey-Fuller	REQM	Raiz do Erro Quadrático Médio
DM	Diebold-Mariano	VAR	<i>Vector Autoregressive</i>
FAC	Função de Autocorrelação	VEC	<i>Vector Error Correction</i>
FACP	Função de Autocorrelação Parcial		

1. Introdução

A previsão de variáveis económicas é uma tarefa difícil pois é impossível de descrever completamente a complexa rede de interações de uma economia através de um modelo simples e parcimonioso. Contudo, George Box (2005) disse que “todos os modelos estão errados, mas alguns são úteis”. Neste sentido, muitas técnicas apareceram ao longo dos anos desde métodos numéricos simples a métodos estocásticos complexos para efeitos de previsão, pelo que a literatura sobre este assunto é vasta. Desta forma, a utilização de modelos e a escolha daquele que melhor se ajusta ao problema em análise deve ser realizada de forma rigorosa e metódica, tendo sempre em consideração a teoria económica.

Conseguir captar a tendência futura do comportamento de variáveis económicas é importante pois uma boa noção da realidade futura permite que a sociedade se adapte e tenha uma intervenção ativa no presente. Por exemplo, supondo um abrandamento económico, os grandes decisores de política económica e monetária podem aplicar medidas para estimular a economia e atenuar os efeitos desse mesmo arrefecimento. No caso oposto, os grandes decisores podem aplicar medidas que evitem os efeitos negativos de uma economia demasiado sobreaquecida e aproveitar o ritmo de expansão desta para aplicar medidas de investimento e resolver problemas estruturais.

O Produto Interno Bruto (PIB) é uma das variáveis mais importantes em qualquer economia pois permite descrever sumariamente a sua evolução com um número agregado. Além disso, o PIB merece sempre a atenção de todos os agentes económicos, constituindo um dado fulcral para a atuação destes.

Através do conhecimento adjacente a cada economia será possível estudar e compreender que variáveis deverão ter influência mais significativa sobre o seu PIB, o que será útil para criar um modelo estatístico que permita representar, aproximadamente, algumas das interações mais importantes na economia e prever o andamento desta.

A Região Administrativa Especial de Macau, localiza-se no Sul do Mar da China e foi a última colónia asiática portuguesa, tendo ainda nos dias de hoje ligações com Portugal a nível cultural e económico. Atualmente, Macau é, principalmente, um centro turístico e com um enorme mercado da indústria de jogo superando, em termos de receitas, a cidade americana de Las Vegas.

Segundo o Anuário Estatístico 2017 (2018), divulgado pela Direção dos Serviços de Estatística e Censos de Macau, o peso das receitas de jogo de Macau em valor acrescentado bruto no PIB de Macau em 2017 foi de 63.0% e 47.2% em 2013 e 2017, respetivamente. Esta diminuição na relevância das receitas de Macau aconteceu após o abrandamento económico da China e o aumento de medidas anticorrupção, o que limitou os gastos supérfluos da população chinesa e, conseqüentemente diminuiu o número de visitantes provenientes da China que despendiam os seus rendimentos na indústria do jogo de Macau.

De acordo com o Anuário Estatístico 2017 (2018) mencionado anteriormente, no ano de 2015, após uma queda de 34.3% das receitas do jogo, o PIB de Macau contraiu 21.5%. No entanto, ao contrário do esperado, segundo a informação estatística disponível, este efeito não se propagou pela economia com efeitos negativos como o aumento do desemprego ou diminuição de salários, possivelmente devido a excedentes acumulados provenientes de anos anteriores.

O objetivo inicial e principal deste trabalho é comparar a *performance* de diferentes modelos econométricos para prever o PIB de Macau de forma a tentar perceber aquele que, eventualmente, melhor se adequa à previsão desta variável. Posteriormente, irá realizar-se a sua respetiva previsão para os quatro trimestres após o final da amostra, ou seja, para o horizonte temporal do segundo trimestre de 2018 até ao primeiro trimestre de 2019.

Numa primeira fase, irão realizar-se testes de raiz unitária e de cointegração para inferir acerca da estacionaridade das séries incluídas neste estudo e possíveis relações de longo prazo entre elas. De seguida, vão estimar-se os modelos de correção de erros vetorial (VEC – *Vector Error Correction*), autorregressivo com variáveis desfasadas (ADL – *Autoregressive Distributed Lags*), ARIMA (*Autoregressive Integrated Moving Average*) e Holt-Winters e verificar aquele que tem, aparentemente, melhor capacidade preditiva. Esta comparação entre modelos será realizada através da Raiz do Erro Quadrático Médio (REQM), Erro Absoluto Médio (EAM) e Erro Absoluto Médio Percentual (EAMP) que são os métodos mais populares para este efeito.

Além disso, será utilizado o teste de Diebold-Mariano de forma a averiguar se as diferenças entre as previsões dos diferentes modelos são significativas.

Os resultados dos testes e critérios anteriores apontaram para uma superioridade da capacidade preditiva do modelo ADL, tanto em termos de previsão estática como dinâmica. A previsão de acordo com este modelo indica um abrandamento para o PIB de Macau em 2018 face ao ano anterior.

O trabalho encontra-se estruturado na seguinte composição. Uma revisão bibliográfica é realizada na secção dois onde se explora um pouco a literatura sobre diferentes abordagens para a modelização da variável fulcral deste trabalho. Na secção

três será realizada uma breve descrição dos dados utilizados. Na secção quatro irá ser apresentada a metodologia seguida na resolução do problema, enquanto na secção cinco, irá efetuar-se uma descrição entre os vários modelos considerados e por fim na secção seis, irá ser realizada uma comparação entre os modelos e terminando na secção sete, com uma reflexão sobre as conclusões a retirar dos resultados obtidos na secção anterior.

2. Revisão Bibliográfica

A modelação e subsequente previsão da variável do PIB é frequentemente um tema de interesse para diferentes organismos desde investigadores particulares a organizações internacionais, para as mais diversas geografias do mundo, o que faz com que seja um tema abordado extensivamente na literatura.

Contudo não existe um consenso relativo aos modelos a utilizar pois cada país terá dinâmicas diferentes, dependerá do tipo de variáveis com a qual se irá abordar o problema existindo, desta forma, inúmeras metodologias exequíveis.

Higgins (2016) aborda a questão relativa à previsão da variável do PIB da China através de um VAR bayesiano (BVAR), comparando com modelos como o AR (*Autoregressive*) e VAR (*Vector Autoregressive*) sem a especificação de uma distribuição *a priori*, mostrando a sua superioridade, apesar de se verificar inferior para os horizontes de previsão mais curtos.

Para a previsão do crescimento do PIB no caso britânico, em Barnett (2014), a abordagem sugerida é diferente, tomando em consideração um modelo VAR com mudanças de regime de forma a acomodar quebras de estrutura. Contudo estes modelos em termos de erros de previsão *out-of-sample* são suplantados, em certas ocasiões, pelos

modelos mais simples (AR e VAR) com exceção do períodos de maior crise onde se encontrava uma maior volatilidade da série, pelo que, nesta situação, os modelos que recorrem a mudanças de regime tornam-se mais adequados para acomodar estas alterações.

Jiang (2017), Kuzin (2011) e Clements (2008) recorrem a modelos MIDAS (*Mixed-Frequency Data Sampling*) face à capacidade destes de utilizar indicadores económicos e financeiros (agregados monetários, vendas a retalho, índices acionistas,...) cuja frequência dos dados difere entre eles. Estes modelos têm revelado boa capacidade preditiva, em especial, no curto prazo.

Outro método habitualmente encontrado na literatura é o modelo de fatores, utilizado frequentemente com um grande número de variáveis explicativas. Aqui pretende-se apurar uma relação linear entre as variáveis explicativas, para que desta forma se obtenham os fatores com os quais se pode construir previsões da variável de interesse. Este método já foi utilizado para a previsão do PIB português em Dias (2015) e também se encontram os casos do PIB da Letónia (Bessonov, 2014), da Alemanha (Antipa, 2012) e do Japão (Urusawa, 2014). Estes modelos revelam uma boa capacidade de previsão superior no curto prazo.

No que concerne à literatura sobre a modelação com o objetivo de prever o PIB da geografia de interesse para este trabalho a literatura é mais escassa. Yang (2018) utiliza um método de computação através de redes neurais artificiais para prever o PIB de Macau, contudo, não é realizada uma comparação entre o desempenho deste método face aos métodos económicos usuais.

3. Análise Descritiva dos Dados

Nesta secção irá realizar-se uma breve apresentação dos dados utilizados e dos modelos empregues para efeitos de previsão do PIB de Macau.

Os dados utilizados são trimestrais com um horizonte temporal que se inicia no primeiro trimestre de 2003 e termina no primeiro trimestre de 2018 pelo que a amostra compreende um total de 61 observações.

Em detalhe, os dados utilizados foram:

- O PIB real de Macau a preços médios de 2016, que representa todas as transações de bens e serviços dentro do país que está mensurado em milhões de patacas (moeda local de Macau);
- As receitas brutas de jogo de Macau, que se refere a todos os jogos de fortuna ou azar realizados no país, mensurado em milhões de patacas;
- O volume de negócios a retalho, mensurado em milhões de patacas;
- E as despesas médias por visitante, medidas em patacas, que estão expurgadas de qualquer gasto efetuado em jogos de fortuna ou azar.

Todos estes dados foram retirados da Direção dos Serviços de Estatística e Censos do Governo da Região Administrativa Especial de Macau.

Foram considerados os logaritmos das variáveis originais de modo a diminuir as diferenças entre valores de períodos temporais diferentes e, principalmente, estabilizar a sua variância. Posteriormente, face aos testes utilizados na próxima secção foi aplicada a diferença a cada uma das variáveis com o objetivo de obter variáveis estacionárias, obtendo desta forma variações em cadeia das variáveis.

As figuras 1 e 2 ilustram o PIB real de Macau, as receitas com o jogo, as vendas a retalho e as despesas médias de cada visitante sendo estas últimas as variáveis com as

quais se pretende prever o PIB. Nestas figuras é possível observar um movimento conjunto e um decaimento de atividade a partir do primeiro trimestre de 2014, facto que pode ser explicado pela diminuição de visitantes provenientes da China. No entanto, desde o terceiro trimestre de 2016, a economia tem conseguido obter valores de crescimentos bastante elevados permanecendo, contudo, ainda num nível inferior à observação mais elevada, que ocorreu no quarto trimestre de 2013.

As variáveis nos outputs de estimação apresentam a seguinte denominação: o PIB de Macau será denominado por “*GDPMO*”; as receitas do jogo por “*REVGAME*”; as vendas a retalho por “*RETSALE*”; e as despesas médias por visitante por “*SPEVIS*”. A utilização do prefixo “L” junto do nome da variável significa que esta foi logaritmicada. Da mesma maneira, o prefixo “D” corresponde à aplicação de diferenças.

4. Metodologia

4.1. Teste de Raiz Unitária

Inicia-se a análise econométrica a cada uma das séries temporais deste trabalho com o estudo da sua ordem de integração, ou seja, pretende-se verificar se estas são estacionárias ou mostram sinais da presença de raízes unitárias.

Quando existe estacionaridade numa série temporal, é possível observar graficamente um comportamento de reversão frequente para o seu nível médio. Esta situação acontece, por exemplo, no caso simples de um processo AR(1),

$$y_t = \alpha + \rho y_{t-1} + \epsilon_t$$

em que o parâmetro da variável dependente desfasada, ρ , é inferior a 1 em módulo, apresentando assim um mecanismo de correção que leva a série para essa mesma média.

No entanto, se a série possuir uma raiz unitária, situação que é algo frequente em séries de natureza económica, como o caso do PIB, então ρ será igual a 1,

$$y_t = \alpha + y_{t-1} + \epsilon_t$$

tendo assim ordem de integração igual a 1 denominando-se este tipo de processos por I(1).

Nesta situação a série é conhecida como um passeio aleatório (com ou sem deriva dependendo se $\alpha \neq 0$ ou $\alpha = 0$) e terá uma tendência estocástica significando assim que deixa de apresentar um comportamento de reversão para a média e passa a apresentar um comportamento em que a série no longo prazo não reverte para esse mesmo nível.

A ausência da característica da estacionaridade nas séries poderá originar problemas nas propriedades estatísticas dos estimadores de um modelo econométrico.

Para resolver esta problemática é habitual aplicar as primeiras diferenças às séries o número de vezes necessário até que esta se torne estacionária, ou seja, I(0) ou introduzir um termo de tendência no modelo caso esta já seja estacionária em torno de uma tendência.

Muitas vezes a observação do gráfico e do correlograma de uma série poderá não ser suficiente para inferir sobre a estacionaridade da série gerando naturais dúvidas ao investigador.

Assim, a literatura propõe que se utilizem testes estatísticos para efeito de deteção de raízes unitárias, sendo que o teste mais frequentemente empregue é o teste de Dickey-Fuller Aumentado ou ADF (*Augmented Dickey-Fuller*). Este teste define a existência de uma raiz unitária para a hipótese nula. A equação de teste consiste na seguinte regressão:

$$\Delta y_t = \alpha + \beta t + \phi y_{t-1} + \sum_{i=1}^k \gamma_i \Delta y_{t-i} + \epsilon_t$$

De acordo com a hipótese nula temos $\phi = 0$ e, portanto, no caso da não rejeição da hipótese nula, existe evidência estatística de uma raiz unitária na série. Caso contrário, esta é estacionária (podendo também ser estacionária em torno de uma tendência). A diferença entre o teste de Dickey Fuller e Dickey Fuller Aumentado é o facto do último, na sua equação de teste, introduzir as diferenças da variável dependente desfasada de forma a controlar a autocorrelação no teste, pelo que é necessário escolher um número de desfasamentos (k) adequado ao efeito.

Existem vários métodos para escolher o valor de k para a realização do teste, nomeadamente através dos critérios de informação AIC, BIC, HQ ou através do método geral para particular (GTS ou *general-to-specific*) em que se escolhe um número de desfasamentos inicialmente elevado, testa-se a significância individual do último desfasamento e remove-se este, caso não seja estatisticamente significativo. Este procedimento é repetido até que o último desfasamento apresente significância estatística, sendo que se costuma definir $\alpha = 0.1$ para o nível de significância, como se pode ver em Lopes (2014).

Outro aspeto a ter em atenção, é a inclusão ou não, de termos determinísticos como tendência (t) e/ou constante, na medida em que o tamanho e a potência do teste podem ser negativamente afetadas. Esta seleção pode ser conduzida através de uma análise gráfica ou através do conhecimento do processo gerador de dados. Segundo Lopes (2014), no caso da análise gráfica se revelar inconclusiva então deve-se seguir a intuição económica na escolha dos termos determinísticos.

Para além do teste ADF, existem outros testes para testar a presença de raízes unitárias como o teste KPSS (1992), Phillips-Perron (1988) e outros, com algumas diferenças, como no caso do teste KPSS que, ao contrário do ADF, define que a série é estacionária sob a hipótese nula. Para corroborar os resultados obtidos com o teste ADF foram também aplicados os testes KPSS e Phillips-Perron que, no entanto, não serão abordados teoricamente. Naturalmente utilizaram-se os mesmos termos determinísticos do teste ADF.

No caso do PIB de Macau e da sua variação em cadeia, pode-se observar na figura 1 que a primeira tem genericamente uma tendência para crescer ao longo do tempo, possuindo dessa forma um comportamento não estacionário. A figura 3 mostra que, após a aplicação das primeiras diferenças, a série já não apresenta esta característica, aproximando-se do comportamento típico de um processo estacionário em torno de uma média nula. O mesmo acontece quando verificamos as figuras 4, 5 e 6 referente às outras variáveis cuja aplicação das primeiras diferenças aparenta transformar a série num processo estacionário.

Na tabela A são apresentados os resultados dos testes ADF das variáveis utilizadas em nível e em primeiras diferenças, com os respetivos termos determinísticos.

Em todas as séries em nível, o teste ADF encontra evidência estatística de uma raiz unitária. Contudo, os testes apontam para a evidência estatística de estacionaridade nas primeiras diferenças das séries, com a exceção das vendas a retalho em que o ADF, mesmo após a diferenciação, evidencia uma raiz unitária. Contudo, tanto o teste KPSS, como o teste de Phillips-Perron apontam para a rejeição da raiz unitária pelo que, face a estes resultados e à observação gráfica da série em primeiras diferenças, assume-se que

esta é estacionária. Nas restantes séries, o KPSS e o PP mostram evidência de estacionaridade, confirmando assim os resultados obtidos pelo teste ADF.

4.2. Teste de Cointegração

Após o estudo relativo à ordem de integração das séries, vai-se verificar se estas são cointegradas entre si. Na sua definição clássica, duas séries y_t e x_t são cointegradas quando são ambas $I(1)$ mas possuem uma tendência estocástica comum fazendo com que a combinação linear entre elas, através de um vetor único, conhecido como vetor de cointegração, resulte num processo estacionário:

$$y_t - \beta x_t = u_t, \text{ com } u_t \sim I(0)$$

A relação de cointegração ($y_t = \beta x_t$) é comumente interpretada como uma relação de longo prazo havendo um mecanismo de equilíbrio entre as variáveis que as fará aproximar uma da outra.

Contudo, é necessário ter em atenção às relações que se pretende estudar pois duas séries podem aparentar ter uma tendência estocástica comum mas, na verdade, não existe qualquer relação entre as duas variáveis, tratando-se de uma regressão espúria. Esta análise, ao contrário das raízes unitárias, trata-se de uma análise no âmbito multivariado devido ao facto de estarmos a estudar relações entre diversas variáveis. A literatura propõe vários testes para a presença de cointegração nas variáveis destacando-se o teste de Philip-Ouliaris, t-MCE, Engle-Granger e Johansen. Dos mencionados, os mais recorrentes são os testes de Engle-Granger e de Johansen.

O teste de Engle-Granger contém algumas fragilidades conhecidas, nomeadamente:

- Aplica-se apenas a uma equação pelo que está limitada a uma relação de cointegração;

- É uma estimação a dois passos pelo que qualquer erro adquirido na primeira será necessariamente transmitido para a segunda;
- Dado ser apenas uma equação significa que haverá uma variável dependente e outra independente, podendo acontecer algumas inconsistências dependendo das variáveis que se definem como dependentes e independentes.

Face às limitações apresentadas pelo teste de Engle-Granger, o teste de cointegração empregue neste trabalho é o teste de Johansen, que utiliza um modelo VAR (*Vector Autoregressive*) para testar a existência de várias relações de cointegração entre as variáveis. O modelo VAR(p) tem a seguinte forma como descrito em Lütkepohl (2005):

$$y_t = v + A_1 y_{t-1} + \dots + A_p y_{t-p} + u_t$$

Com y_t a corresponder a um vetor I(1) m-dimensional (sendo este vetor no exercício em questão constituído pelas variáveis GDPMO, REVGAME, RETSALE e SPEVIS) e $u_t \sim RB(0, \Sigma_u)$. Por sua vez este modelo VAR, caso exista cointegração, é posteriormente representado em forma de um modelo VEC (*Vector Error Correction Model*).

$$\Delta y_t = v + \Pi y_{t-1} + \Gamma_1 \Delta y_{t-1} + \dots + \Gamma_{p-1} \Delta y_{t-p+1} + u_t$$

Com o termo $\Pi = -A(1) = -(I - A_1 - \dots - A_p)$ a representar o termo de correção de longo prazo. O teste de Johansen (1988, 1991 e 1995) incide sobre a característica da matriz Π . Se a matriz tiver característica máxima, $Rank(\Pi) = K$, então estamos perante uma situação em que todos os vetores da matriz são linearmente independentes pelo que y_t é um vetor de variáveis I(0). No caso oposto, se a matriz tiver característica nula, ou seja, $Rank(\Pi) = 0$, então Π é um vetor de variáveis I(1) não cointegradas. O caso mais interessante a ser estudado é quando a característica da matriz é $0 < rank(\Pi) = r < K$, pelo que nesse caso deverão existir r vetores linearmente independentes, logo r relações de cointegração no vetor y_t .

Johansen propôs dois testes para testar a característica da matriz e determinar o número de relações de cointegração entre as variáveis que compõem y_t : o teste do traço e o teste do valor próprio máximo. Para além do método da realização do teste ser diferente, as hipóteses adjacentes a estes diferem também uma da outra.

No caso do teste do traço, a hipótese nula é $H_0: r = r^*$ e a hipótese alternativa é $H_1: r > r^*$, ao passo que, no teste do valor próprio máximo, a hipótese nula é igual à anterior mas a hipótese alternativa é $H_1: r = r^* + 1$. Estes testes tratam-se de testes sequenciais, pelo que o teste irá continuar até à não rejeição da hipótese nula.

Uma observação a realizar é a semelhança da forma do modelo VEC com a equação do teste ADF mas com a estrutura de um VAR, e à semelhança do ultimo também no primeiro é necessário ter em consideração a escolha dos termos determinísticos para a realização do teste. Desta feita, podem existir cinco casos relativamente aos termos determinísticos, sendo que a escolha dos termos determinísticos pode resultar em estimativas diferentes de r .

No caso em estudo, após uma análise gráfica foi considerado o caso em que se assume apenas uma constante na relação de cointegração e em que os dados não revelam uma tendência determinística.

Para iniciar a análise de cointegração é necessário numa primeira instância criar um modelo VAR e determinar o número de defasamentos a utilizar. Para o efeito, o *Eviews* dispõe de um leque variado de critérios de seleção para o número de defasamentos como o AIC (*Akaike Information Criterion*), SC (*Schwarz Information Criterion*), HQ (*Hannah-Quinn Criterion*), FPE (*Final Prediction Error*) e o teste LR (*Likelihood Ratio*), todos estes na sua versão multivariada. Na tabela B apresentam-se os resultados destes critérios, com o SC a indicar um defasamento ($p = 1$), o HQ dois defasamentos ($p =$

2) e os restantes quatro defasamentos ($p = 4$). Face ao número de observações disponíveis e ao já grande número de variáveis incluídas, foi considerado o modelo mais parcimonioso o que, conseqüentemente, significa que o número de defasamentos mais adequado é o VAR(1).

Antes de avançar para o teste de cointegração é conveniente verificar a presença de autocorrelação nos erros do modelo, através de um teste LM multivariado e realizar um teste de normalidade, através de um teste Jarque-Bera, também este na sua forma multivariada, pois as propriedades do teste de Johansen são sensíveis a estas características.

No modelo VAR(1), apesar do teste Jarque-Bera não rejeitar a normalidade dos erros, o teste LM rejeita a hipótese nula de ausência de autocorrelação nos erros, como é possível observar na tabela C. Para solucionar esta questão foram verificados os gráficos de correlações das várias variáveis de forma a detetar qual o defasamento problemático, pelo que, desta feita, experimentou-se um modelo VAR(4), mas com restrições no segundo e terceiro defasamento, de forma a evitar um número excessivo de parâmetros estimados no modelo.

Foram realizados novamente os testes anteriores, que se encontram na tabela C e D. Contudo, com o modelo VAR(4) restrito, já não se rejeita nem a hipótese de ausência de autocorrelação nos erros nem a hipótese da normalidade.

Apesar destas discrepâncias foi aplicado o teste de Johansen descrito anteriormente tanto ao modelo VAR(1) como ao VAR(4), como se verifica nas tabelas E e F. Tendo em consideração os termos determinísticos abaixo referidos, ambos os testes apontam para a existência de cointegração no VAR(1): no caso do teste do valor próprio máximo, a hipótese nula não foi rejeitada para uma relação de cointegração ($r = 1$), enquanto o teste

do traço aponta para duas relações de cointegração ($r = 2$). Contudo, no caso do VAR(4), o modelo aparentemente bem especificado, relativamente às propriedades dos resíduos, nem o teste do traço nem o do valor próprio máximo detetaram qualquer relação de cointegração.

A razão que justifica este resultado poderá estar relacionada com uma possível quebra na estrutura da série criando um *level shift* que ocorre no segundo trimestre de 2014, e que se pode verificar graficamente em todas as séries. Como é ilustrado em Gregory (1996), o efeito de uma quebra de estrutura na série resulta numa maior dificuldade em rejeitar a hipótese de ausência de cointegração, devido à introdução de um efeito de raiz unitária na relação de cointegração. Para corrigir este efeito, Johansen et al. (2000) propôs um teste para a deteção de cointegração na presença de quebras de estrutura na série, baseado no teste anterior mas com algumas modificações. A formulação para realizar o teste com quebras de estrutura proposto por Johansen é o seguinte:

$$\Delta \mathbf{y}_t = (\boldsymbol{\Pi}, \boldsymbol{\Pi}_j) \begin{pmatrix} \mathbf{y}_{t-1} \\ t \end{pmatrix} + \boldsymbol{\mu}_j + \sum_{i=1}^{p-1} \boldsymbol{\Gamma}_i \Delta \mathbf{y}_{t-i} + u_t$$

A hipótese a considerar para verificar a cointegração, na situação em que se contempla apenas uma quebra no nível da série, designa-se como $H_c(r)$ e é:

$$H_c(r): \text{rank}(\boldsymbol{\Pi}, \boldsymbol{\mu}_1, \dots, \boldsymbol{\mu}_q) \leq r \text{ e } (\boldsymbol{\Pi}_1, \dots, \boldsymbol{\Pi}_q) = 0$$

Sendo que q representa o número de quebras na série. Este teste utiliza uma distribuição diferente da do teste de Johansen dependendo também do caso que se pretende estudar (quebra no nível, quebra na tendência, quebra no nível e tendência). O *software JMulti* permite realizar o teste do traço com a possibilidade de introduzir até duas quebras de estrutura, tanto em nível como em nível e tendência. Realizado o teste, apenas com constante e declarando uma quebra de estrutura na observação mencionada

anteriormente (2º trimestre de 2014), corresponde ao resultado da tabela G. Como é possível observar, o teste mostra evidência estatística para a existência de duas relações de cointegração ($r = 2$). Note-se que, no processo, foi aplicado o teste LM e agora não se encontrou evidência estatística de autocorrelação nos resíduos deste modelo.

Além disso face à evidência de cointegração, resultado este mais intuitivo do ponto de vista económico, é justificável representar o VAR(4) sob forma de um modelo VEC com duas relações de cointegração, com restrições no segundo e terceiro desfasamento e uma variável *dummy* inserida como variável exógena, com o objetivo de representar a quebra de estrutura com início no segundo trimestre de 2014.

5. Modelos

5.1. VEC

Face ao exposto anteriormente, o modelo VAR(4) restrito foi estimado sob forma de um VEC com duas relações de cointegração. Para verificar a correta especificação do modelo VEC, foi testada a presença de autocorrelação nos resíduos através de um teste LM. Para além deste, também se verificou a normalidade dos resíduos através de um teste de Jarque-Bera. Os testes não mostraram evidência estatística da presença de autocorrelação ou de desvios da hipótese da normalidade dos erros.

Foi realizado um teste de Wald para testar a causalidade de Granger no sistema de equações do modelo VEC. Na tabela H encontram-se os resultados destes testes. De uma forma geral, pode-se observar que, em conjunto, todas as variáveis melhoram as previsões da respetiva variável de interesse. Como era esperado, as receitas do jogo (REVGAME),

face à sua importância na economia, ajudam a prever a variável do PIB de Macau (GDPMO), tal como era expetável que a última não ajudasse a prever a primeira.

Para além disto rejeita-se a hipótese de que as variáveis dos gastos médios por visitante (SPEVIS) e das vendas a retalho (RETSALE) não causarem à Granger a variável das receitas do jogo. Contudo é possível que haja alguma relação entre a variável SPEVIS e a variável REVGAME pelo facto do aumento dos gastos médios implicar um maior número de visitantes em Macau, e consequentemente, um maior número de possíveis clientes para a indústria do jogo.

Tanto a variável REVGAME como a variável GDPMO aparentam melhorar as previsões sobre a variável dos gastos médios por visitante. Porventura a relação que causa mais estranheza é como tanto a variável REVGAME como a RETSALE, melhoram as previsões entre si, variáveis estas que do ponto de vista de atividade económica não deveriam ter relação entre elas.

5.2. ADL

A metodologia ADL (*AutoRegressive with Dependent Lag*) permite estimar um modelo econométrico dinâmico em que se inclui como regressores tanto a variável de interesse desfasada como outras variáveis também desfasadas. Assim, este é um modelo interessante para caracterizar as relações dinâmicas entre diferentes variáveis e, simultaneamente, permite alguma flexibilidade na escolha do modelo mais adequado. Na sua forma mais geral, o modelo ADL adota a seguinte expressão:

$$y_t = \sum_{i=1}^r \alpha_i y_{t-i} + \sum_{i=0}^s \beta_i x_{t-i} + \epsilon_t$$

Para além da vantagem anteriormente referida, é possível reescrever a regressão de modo a encontrar a representação na forma de correção de erros (MCE), com a qual se pode estudar o parâmetro de correção de curto prazo e o multiplicador de longo prazo. À semelhança do modelo VEC é também possível testar a existência de uma relação de cointegração entre as variáveis através deste modelo sendo que essa questão não será abordada aqui. O modelo ADL na sua representação MCE tem a seguinte expressão:

$$\Delta y_t = \phi[y_{t-1} - \lambda x_{t-1}] + \sum_{i=1}^{r-1} \delta_i \Delta y_{t-i} + \sum_{i=0}^{s-1} \gamma_i \Delta x_{t-i} + \epsilon_t$$

Com $\lambda = B(1)/A(1)$, a representar o multiplicador de longo prazo e ϕ que corresponde ao parâmetro de correção de erros.

Para efeitos de modelação, irá estimar-se o modelo na forma de Bardsen, dado que esta assume uma expressão mais simples e permite encontrar diretamente o parâmetro de correção de erros e, conseqüentemente, o multiplicador de longo prazo. A forma de Bardsen assume a seguinte expressão:

$$\Delta y_t = -A(1)y_{t-1} + \sum_{i=1}^{r-1} \delta_i \Delta y_{t-i} + B(1)x_{t-1} + \sum_{i=0}^{s-1} \gamma_i \Delta x_{t-i} + \epsilon_t$$

A abordagem para chegar ao modelo ideal corresponde ao método do modelo mais geral para o particular em que se inicia o processo com um modelo sobreparameterizado e são removidos os desfasamentos em que não se encontra significância estatística individual dos regressores desfasados através da habitual estatística-t para $\alpha = 0.1$. Durante o procedimento devem realizar-se os habituais testes de especificação como os testes de autocorrelação, heterocedasticidade, normalidade e de quebra de estrutura. Neste trabalho, o processo iniciou-se com quatro desfasamentos na variável dependente e nas variáveis independentes e foram sendo retirados sucessivamente os desfasamentos não

estatisticamente significativos. Na tabela I é possível observar os resultados da estimação do modelo final, com os respetivos valores-p e estatísticas-t. Apesar da inexistência de significância estatística das variáveis não diferenciadas LRETSALE e LSPEVIS, foram mantidas no modelo devido ao facto de constituírem parte da relação de longo prazo.

Foram realizados testes de especificação, em que os testes de heterocedasticidade condicional não rejeitam a sua hipótese nula correspondente. A mesma situação verifica-se quando se averigua a existência de autocorrelação nos erros através do teste LM em que não se rejeita a hipótese de não autocorrelação dos erros. Finalmente, os testes F e *Reset* deram indicações, respetivamente, de que, pelo menos, um regressor é estatisticamente significativo e que o modelo na sua forma linear está bem especificado. Com os testes anteriores, conclui-se que não existe evidência de má especificação, pelo que se assume a validade estatística do modelo estimado e dos resultados obtidos.

O primeiro facto a observar é a significância estatística do parâmetro ϕ , que no output da estimação é representado pela variável LGDPMO, com o qual se pode concluir a existência de um mecanismo de correção de erros no modelo, tendo em consideração que a condição necessária para estabilidade, $A(1) > 0$ aparenta ser satisfeita, tendo em conta que apenas temos acesso a valores estimados. Outro aspeto importante a destacar é o sinal do parâmetro, que neste caso é negativo, encontrando-se de acordo com o mecanismo de correção dos erros do modelo ADL.

O modelo estimado no *output* está sob a forma de Bardsen, pelo que na sua forma de MCE a estimação assume a seguinte expressão:

$$\begin{aligned}
DLGDPMO_t = & -0.262[LGDP MO_{t-1} + 0.494 LREVGAME_{t-1} - 0.04 LRETSALE_{t-1} \\
& - 0.024 LSPEVIS_{t-1}] - 0.137DLGDPMO_{t-3} + 0.663 DLGDPMO_{t-4} \\
& + 0.453 DLREVGAME_t + 0.172 DLREVGAME_{t-3} \\
& - 0.268 DLREVGAME_{t-4} - 0.296DLRETSALE_{t-2} + 0.161DL SPEVIS_t \\
& - 0.162DL SPEVIS_{t-4}
\end{aligned}$$

Para realizar previsão sobre a variável do PIB de Macau, será necessário, separadamente, realizar previsão sobre as variáveis independentes visto que serão necessárias observações futuras destas. A abordagem seguida para obter valores futuros para as variáveis independentes será através de modelos ARIMA, tema que será explorado na próxima secção.

5.3. Autoregressive Integrated Moving Average (ARIMA)

O modelo ARIMA corresponde à generalização do bem conhecido modelo ARMA para séries não estacionárias. Os modelos ARMA (*AutoRegressive Moving Average*) são modelos univariados que assumem que o processo gerador de uma série temporal genérica y_t obedece à seguinte expressão:

$$(1 - \phi_1 B - \dots - \phi_p B^p)y_t = (1 - \theta_1 B - \dots - \theta_q B^q)\varepsilon_t$$

Com y_t a representar a variável dependente, ε_t é o termo de erro que deve seguir um processo de ruído branco e B o operador *lag*. A ordem do processo é descrita como ARMA (p,q), em que p refere-se ao número de desfasamentos da componente AR e q ao número de desfasamentos da componente MA. No entanto, este processo resulta apenas quando existe estacionaridade das variáveis, sendo neste âmbito que a extensão ARIMA é útil pois possibilita a utilização de variáveis não estacionárias através da sua

diferenciação representando-se dessa forma como ARIMA (p,d,q), sendo que o d representa o número de diferenças e adotando a seguinte expressão:

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - B)^d y_t = (1 - \theta_1 B - \dots - \theta_q B^q) \varepsilon_t$$

Para além desta, existem outras extensões da classe ARMA onde se permite também sazonalidade, acrescentando mais alguma complexidade ao modelo, passando a representar-se como SARIMA (p,d,q)(P,D,Q).

A expressão passa a assumir a seguinte forma:

$$\Phi_P(B^S)\phi_p(B)(1 - B)^d(1 - B^S)^D y_t = \theta_q(B)\Theta_Q(B^S)\varepsilon_t$$

As ordens P, D e Q têm o mesmo significado das anteriores, ou seja, ao número de desfasamentos mas da parte puramente sazonal do modelo. Este modelo foi popularizado pela metodologia Box-Jenkins em que através de um conjunto de passos se pode chegar ao modelo ARIMA, iniciando-se pela identificação do modelo. Nesta fase, é necessário verificar a estacionaridade da série através de observação gráfica ou testes de raízes unitárias mencionados anteriormente e inferir acerca da presença de sazonalidade. Adicionalmente, é necessário visualizar o gráfico da FAC (Função de Autocorrelação) e FACP (Função de Autocorrelação Parcial) de modo a deduzir quais os níveis de diferenciação e ordens para os operadores AR e MA necessárias para que os resíduos se assemelhem a um processo ruído branco. No caso dos operadores sazonais, o tratamento é semelhante, tendo em atenção à existência de algum padrão na significância dos desfasamentos nas funções de autocorrelação. Após a identificação do modelo e a sua consequente estimação, é necessário analisar a significância estatística dos vários regressores e efetuar uma análise de autocorrelação dos erros através de um teste de Ljung-Box e da normalidade dos erros com um teste Jarque-Bera. Findo isto caso exista mais que um modelo, então deverá recorrer-se aos critérios de informação como o AIC,

SC e HQ para selecionar aquele que minimiza a perda de informação e, consequentemente, melhor se ajusta aos dados atribuindo maior importância ao critério AIC no caso em estudo. Na Figura 7, é possível observar a FAC e FACP da série do PIB de Macau às primeiras diferenças (DLGDPMO). Após a observação destas e subsequente experimentação, chega-se à conclusão, que em termos de ajustamento das funções de autocorrelação os modelos mais corretos são ARIMA (0,1,0) (1,0,0) e ARIMA (0,1,0) (1,0,1). Em ambos os modelos, existe evidência estatística a favor da não autocorrelação dos resíduos segundo o teste de Ljung-Box e da normalidade dos erros pelo teste de Jarque-Bera, ambos com uma dimensão de teste de 5%, pelo que se pode concluir que os resíduos aparentam seguir um processo ruído branco. Contudo, o parâmetro MA sazonal não tem significância estatística a um nível de 5% ou 10%, e quando comparado com o critério de informação AIC observa-se que o modelo ARIMA (0,1,0)(1,0,0) obtém de um melhor ajustamento aos dados. Deduz-se então que o modelo ARIMA mais adequado para realizar previsão da variável LGDPMO é o modelo anteriormente mencionado. Para as restantes variáveis, que serão necessárias para realizar previsão recorrendo ao modelo ADL, os modelos ARIMA são os seguintes: para as receitas do jogo é usado um SARIMA (2,0,0)(0,1,0); para as despesas médias por visitantes é um modelo SARIMA (1,0,0)(1,1,0); e para as vendas a retalho recorre-se a um modelo ARIMA (2,1,0).

5.4. Metodologia Holt-Winters

O método de Holt-Winters criado por Holt e Winters (1957) é um método determinístico de alisamento exponencial em que se utilizam apenas os valores históricos da própria série, ponderando as observações mais antigas com um peso inferior e as mais recentes com um peso maior. Em particular, a influência das observações de acordo com a sua antiguidade tem um decaimento exponencial.

Este método é bastante simples de aplicar, sendo esta simplicidade uma das razões pela qual este método é popularmente utilizado e será usado aqui. Outra razão é que permite modelar os movimentos sazonais da série ao contrário de outros métodos como o *Simple Exponential Smoothing* ou *Double Exponential Smoothing*.

No método de Holt-Winters com sazonalidade existem dois métodos diferentes para considerar a sazonalidade: multiplicativa e aditiva. Como visto em Makridakis (2008), no primeiro caso, o fator sazonalidade varia consoante o nível da série, contudo se este se mantiver constante, então o segundo caso torna-se mais adequado.

Para o PIB de Macau, irá ser aplicado, por observação do gráfico, o modelo de Holt-Winters com sazonalidade aditiva, devido ao facto de se ter encontrado evidência de possível sazonalidade, sendo que os padrões desta não aparentam alterar-se substancialmente com o tempo. Através do *Eviews* é possível utilizar parâmetros escolhidos pelo investigador ou calcular parâmetros otimizados. Neste estudo foi utilizada a abordagem da otimização dos parâmetros. Para mais informação sobre esta metodologia ver também Caiado (2011).

6. Resultados Empíricos

6.1. Amostra de Previsão

Com o objetivo de estudar a robustez das previsões e, conseqüentemente, se existem diferenças significativas entre modelos para diferentes intervalos de tempo, foram construídas previsões para quatro períodos temporais distintos, ou seja, para quatro diferentes amostras de teste às previsões. Desta forma, também o período de estimação será diferente para as quatro amostras de teste. Com isto, os quatro casos são os seguintes:

- O primeiro período de estimação compreende as observações do primeiro trimestre de 2003 até ao quarto trimestre de 2013 pelo que o período de previsão irá desde o primeiro trimestre de 2014 até ao primeiro trimestre de 2018 (17 observações);
- O segundo período de estimação será do primeiro trimestre de 2003 até ao quarto trimestre de 2014, com o período de previsão do primeiro trimestre a ir desde 2015 até ao primeiro trimestre de 2018 (13 observações);
- O terceiro período de estimação inclui as observações desde o primeiro trimestre de 2003 até ao quarto trimestre de 2015 e o período de previsão será do primeiro trimestre de 2016 até ao primeiro trimestre de 2018 (9 observações);
- Por fim, a última amostra de teste será do primeiro trimestre de 2017 até ao primeiro trimestre de 2018 (5 observações), com as restantes a servirem como amostra de estimação do modelo.

Serão calculadas tanto as previsões estáticas como as dinâmicas para estes quatro casos.

6.2. Metodologia de Previsão

As previsões construídas serão do tipo dinâmico e estático. A previsão dinâmica constrói-se a partir do resultado das próprias previsões anteriores para todos os subsequentes momentos de previsão ($n+2, n+3, \dots$). A exceção é a primeira previsão ($n+1$) em que é utilizada a última observação realizada da série tal como na previsão estática.

Já as previsões estáticas são construídas a partir das observações efetivamente realizadas pela série em todas as previsões ($t+1, t+2, t+3, \dots$) com a equação correspondente à previsão a um passo.

6.3. Metodologia de Comparação

Os métodos utilizados para comparar as previsões na amostra de teste serão os habituais procedimentos de medição relativa dos erros de previsão, ou seja, a raiz do erro quadrático médio (REQM), erro absoluto médio (EAM) e erro absoluto médio percentual (EAMP). O modelo que obtiver o menor valor nestes procedimentos será aquele que consegue, em média, “melhores” previsões na amostra de teste.

Apesar da comparação entre estas diferentes medidas permitir uma noção da qualidade relativa das previsões entre os diferentes métodos em competição, ter-se-á um maior rigor estatístico se for possível testar se as diferenças entre os erros de previsão dos diferentes modelos são ou não estatisticamente significativas.

Para abordar esta questão, Diebold e Mariano (1995) propuseram o teste de Diebold-Mariano (DM) com o intuito de testar se a diferença entre os erros de previsão de dois métodos são estatisticamente significativos. Este teste compara os erros de previsão através de uma função de perda obtida da seguinte forma. Num primeiro momento é

necessário estabelecer os dois modelos que se pretende comparar, calcular as diferenças entre os valores observados $\{Y_t: t = 1, 2, \dots, T\}$ e as respectivas previsões $\{\hat{Y}_{1t}: t = 1, 2, \dots, T\}$ e $\{\hat{Y}_{2t}: t = 1, 2, \dots, T\}$ de forma a obter os erros entre estas, ou seja, $e_{it} = \hat{Y}_{it} - Y_t$, com o índice $i = 1, 2$ a corresponder às previsões do modelo 1 e 2, respetivamente. Posteriormente, ambos os erros de previsão deverão ser escritos sob forma de uma função $g(e_{it}) = g(\hat{Y}_{it} - Y_t)$. As funções mais habitualmente usadas são a quadrática, $g(e_{it}) = e_{it}^2$ e a do valor absoluto, $g(e_{it}) = |e_{it}|$.

Desta forma, pode-se então construir o *loss differential* que se trata apenas da diferença entre o quadrado ou o módulo dos erros de previsão, $d_t = g(e_{1t}) - g(e_{2t})$. O teste baseia-se em testar se o valor esperado do *loss differential*, d , é zero para todo o horizonte de previsão.

A hipótese nula do teste DM corresponde a $H_0: E(d_t) = 0$ pelo que a rejeição desta hipótese indicará evidência estatística favorável à existência de diferenças relevantes entre os erros de previsão dos dois modelos considerados. A estatística de teste segue uma distribuição normal *standard* para uma dimensão da amostra de teste suficientemente grande.

Ao contrário de outras estatísticas para o mesmo fim, o teste DM beneficia de condições menos restritas permitindo que, numa situação que os erros não disponham de uma distribuição normal, o teste mantenha uma dimensão razoável em grandes amostras. Contudo, em pequenas amostras a dimensão do teste sofre algumas distorções. Para corrigir este facto, Harvey, Leybourne e Newbold (1997) desenvolveram uma variação do teste DM com a seguinte correção para pequenas amostras:

$$DM^* = \frac{DM}{\left[\left[T + 1 - 2h + \frac{h(h-1)}{T} \right] / T \right]^{1/2}}$$

No que concerne à distribuição desta estatística, ao contrário da estatística DM que seguia uma distribuição normal, a estatística DM* segue uma distribuição *t-student* com T-1 graus de liberdade. De forma a ter em consideração a autocorrelação presente na série do *loss differential* recorre-se ao estimador de Newey-West.

Os testes efetuados com estas duas estatísticas serão realizados com as previsões estáticas e dinâmicas do horizonte temporal iniciado no primeiro trimestre de 2014 e que termina no primeiro trimestre de 2018. Para a previsão estática, dado que é sempre uma previsão a um passo, temos $h = 1$. A função $g(.)$ para os erros de previsão será a função quadrática.

6.4. Comparação de resultados

O quadro 1 apresenta os resultados obtidos com procedimento descrito anteriormente, relativo às comparações entre os diferentes métodos de previsão para o período desde o primeiro trimestre de 2014 e o primeiro trimestre de 2018.

Quadro 1- Resultados dos critérios de comparação para o período 2014-2018

Método	Critério	VEC	ADL	Holt Winters	ARIMA
Dinâmica	REQM	0.114698	0.061466	0.307897	0.064029
	EAM	0.102718	0.044932	0.285014	0.054562
	EAMP	0.886462	0.390597	2.487421	0.474241
Estática	REQM	0.029859	0.013883	0.050874	0.057930
	EAM	0.025016	0.011423	0.038220	0.046017
	EAMP	0.217546	0.099230	0.331186	0.399465

Tanto na previsão estática como na dinâmica, existe uma clara preferência pelo método ADL com um desempenho superior para todas as métricas em comparação com os restantes modelos. Na previsão dinâmica o modelo ARIMA registou erros inferiores

ao modelo VEC, algo que não se verifica na previsão estática com o segundo a obter um desempenho superior ao primeiro. O modelo Holt-Winters, entre os quatros modelos, sofre o pior desempenho em termos de previsão dinâmica, possivelmente devido à natureza mais errática da série que não é bem acompanhada por um simples modelo de alisamento. Contudo este método consegue superar o desempenho do modelo ARIMA na previsão estática.

Nas restantes amostras de teste consideradas, que se podem verificar em anexo nas tabelas J, K e L, o modelo ADL conserva-se na qualidade de melhor modelo em todas medidas da capacidade preditiva e tipos de previsão. Na janela de previsão compreendida entre 2015 e 2018, tal como sucedeu no período entre 2014 e 2018, o modelo VEC na previsão estática supera os restantes, excluindo o modelo ADL, enquanto o modelo ARIMA consegue melhores resultados na previsão dinâmica.

No horizonte temporal de 2016-2018, os erros de previsão do modelo VEC, em ambas as metodologias de previsão são inferiores tanto ao modelo ARIMA como ao modelo Holt-Winters.

Na amostra de teste que compreende um total de cinco observações entre 2017 e 2018 os resultados são bastante próximos tanto para previsão dinâmica como para a estática. Os modelos mais simples como o Holt-Winters e ARIMA conseguem resultados comparáveis ao “melhor” modelo referido anteriormente, ou seja, ao ADL. Neste horizonte, o VEC revela o pior desempenho entre os quatro modelos, mas mantendo valores para os erros próximos daqueles observados no horizonte de 2016-2018.

Tal como referido anteriormente, foi efetuado o teste DM e DM-HLN com o objetivo de averiguar se as diferenças dos erros de previsão dos modelos são estatisticamente significativas.

A tabela M revela os resultados dos vários testes DM e DM-HLN para a amostra de 2014-2018 em termos de previsão dinâmica. Os resultados mostram com uma dimensão de teste de 5%, não existe evidência estatística para diferenças significativas entre as previsões dos modelos ADL, VEC e ARIMA. A respeito do modelo Holt-Winters, o resultado é menos favorável indicando diferenças significativas entre erros de previsão referentes a este método face aos restantes.

Para a previsão estática na tabela N, os resultados diferem da previsão dinâmica, pelo que nesta situação, todos os modelos mostram diferenças significativas dos seus erros de previsão para aquele período face aos erros produzidos pelo modelo ADL. O teste para erros de previsão entre o modelo Holt-Winters e os modelos ARIMA e VEC mostra que não existe uma diferença entre os erros de previsão, contudo os erros do modelo ARIMA quando comparados com os erros do modelo VEC revelam uma diferença, existindo assim uma preferência pelo último.

6.5. Previsão

Foram construídas previsões para o período compreendido entre o primeiro trimestre de 2018 e o primeiro trimestre de 2019. As tabelas O e P apresentam um pequeno histórico das observações passadas do PIB de Macau, em nível e em crescimento homólogo, e as previsões correspondentes para os vários modelos considerados anteriormente.

Como referido anteriormente, para realizar previsão do PIB através do modelo ADL foi necessário recorrer a modelos ARIMA para determinar os valores futuros das restantes variáveis.

As projeções de todos os modelos sugerem que a economia de Macau vai verificar um abrandamento ao longo do horizonte de previsão, face ao crescimento médio anual de 9.2% do ano 2017.

O modelo ADL projeta que o crescimento médio anual para o ano de 2018, que inclui o primeiro trimestre já realizado e três trimestres projetados, será de 6.8%. Por seu lado, o VEC, o Holt-Winters e o ARIMA preveem 8.7%, 8.8% e 9.1%, respetivamente. Para o primeiro trimestre de 2019, as previsões do modelo ADL assinalam um abrandamento considerável para 3.9%, cifrando-se assim o crescimento do PIB a um nível bastante inferior ao crescimento observado no mesmo período do ano anterior. Os restantes modelos, para o mesmo momento de tempo, apresentam resultados ligeiramente diferentes com os modelos ARIMA, VEC e Holt-Winters a preverem taxas de crescimento de 9.6%, 5.0% e 3.1%, respetivamente. Na figura 7 é possível observar uma comparação gráfica para as previsões entre os diferentes modelos em termos de crescimento homólogo.

7. Conclusão

Como referido na introdução do trabalho, é importante ter o conhecimento e as ferramentas importantes para auxiliar e facilitar a tomada de decisão. Esta tomada de decisão pode referir-se, tanto à política orçamental e/ou monetária seguida por entidades governamentais de um país, como a decisão de uma empresa expandir ou não a sua atividade para o estrangeiro.

A Região Autónoma de Macau, face às ligações históricas e culturais com Portugal, proporciona um elo de ligação entre as duas regiões, permitindo uma acomodação mais

facilitada de empresas financeiras ou não financeiras. Para além disto, em termos de proximidade, permite ainda um ponto de mais fácil acesso no mercado asiático, nomeadamente, a República Popular da China, considerada a segunda maior potência do mundo, que face à crescente dimensão do seu mercado interno, origina numerosas oportunidades a explorar.

A abordagem econométrica é uma ferramenta que permite a modelação de dados históricos e, posteriormente, uma aproximação para o futuro das variáveis de interesse, que neste trabalho é a variável do Produto Interno Bruto, *proxy* para o desenvolvimento económico do país.

Foi iniciada a análise às variáveis em termos da sua estacionaridade e posteriormente foi testada a existência ou não de cointegração entre o PIB de Macau e as restantes variáveis, através da metodologia multivariada com o teste de Johansen.

Após o estudo às variáveis ajustaram-se os dados através de diferentes modelos como o modelo VEC, apenas possível após a existência de cointegração num contexto VAR, ARIMA, ADL e Holt-Winters. Estes modelos foram comparados pela sua capacidade preditiva através de critérios como o REQM, EAM e EAMP e dos testes de Diebold-Mariano, que em conjunto, apontaram para o modelo ADL como aquele com melhor capacidade preditiva prevendo este modelo que, em termos médios, a taxa de crescimento para Macau em 2018 apresente valores na ordem dos 6.8%. Por seu lado, o primeiro trimestre de 2019 deverá apresentar valores na ordem de 3.9%.

As principais vantagens dos métodos Holt-Winters e ARIMA são a sua relativa facilidade de computação e modelação, sendo este um ponto considerado mais fraco dos modelos ADL e VEC.

A vantagem do VEC face ao ADL deve-se ao facto de, com exceção da variável do PIB de Macau, o ADL requer que, para prever a variável do PIB, sejam estimados modelos adicionais para as restantes variáveis explicativas, variáveis essas que no modelo VEC são estimadas em simultâneo, ainda que este facto possa transformar-se numa vantagem caso seja necessário um tipo de modelação diferente para as restantes variáveis, modelação esta que possibilite um ajustamento mais personalizado caso a caso. O modelo VEC é bastante complexo pelo que requer uma amostra relativamente grande para ser estimado, não sendo adequado para variáveis cujo número de observações é baixo.

8. Bibliografia

- Box, G. E., Hunter, J. S., & Hunter, W. G. (2005). *Statistics for experimenters: design, innovation, and discovery* (Vol. 2). New York: Wiley-Interscience.
- Caiado, J. (2011). *Métodos de Previsão em Gestão com Aplicações em Excel*, 1ª Ed. Lisboa: Edições Sílabo.
- Dickey, D. A. e Fuller, W. A. (1979). Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association* 74, 427-431.
- Diebold, F. X. e Mariano, R. S. (1995). Comparing predictive accuracy. *Journal of Business and Economic Statistics* 13, 253-263.
- Direcção dos Serviços de Estatística e Censos (2018). *Anuário Estatístico 2017*. Macau: DSEC.
- Gregory, A. W. e Hansen, B. E. (1996). Residual-based tests for cointegration in models with regime shifts. *Journal of Econometrics* 70, 99-126.
- Holt, C. C. (1957). Forecasting seasonal and trends by exponentially weighted moving averages. Office of Naval Research, Research Memorandum No.52.
- Johansen, S. (1988). Statistical Analysis of Cointegration Vectors. *Journal of Economic Dynamics and Control* 12, 231-254.
- Johansen, S. (1991). Estimation and Hypothesis Testing of Cointegration Vectors in Gaussian Vector Autoregressive Models. *Econometrica* 59, 1551-1580.
- Johansen, S. (1995). *Likelihood-based Inference in Cointegrated Vector Autoregressive Models*. Oxford: Oxford University Press.

- Johansen, S., Mosconi, R. e Nielsen, B. (2000). Cointegration analysis in the presence of structural breaks in the deterministic trend. *Econometrics Journal* 3, 216-249.
- Harvey, D., Leybourne, S., e Newbold, P. (1997). Testing the equality of prediction mean squared errors. *International Journal of Forecasting* 13, 281–291.
- Lütkepohl, H. (2005). *New Introduction to Multiple Time Series Analysis*. Springer.
- MacKinnon, J. (1996). Numerical Distribution Functions for Unit Root and Cointegration Tests. *Journal of Applied Econometrics* 11, 601-618.
- Makridakis, S., Wheelwright, S. C., e Hyndman, R. J. (2008). *Forecasting methods and applications*. John Wiley & Sons.
- Kwiatkowski, D., Phillips, P. C., Schmidt, P., e Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?. *Journal of econometrics*, 54(1-3), 159-178.
- Lopes, A. S. (1999). Modelos DL e ADL, Raízes Unitárias e Cointegração: uma Introdução. Lisboa: CEMAPRE, ISEG.
- Lopes, A. S. (2014). *Raízes Unitárias – Uma Introdução*. ISEG – UL.
- Phillips, P. C. B. e Perron, P. (1988). Testing for a Unit Root in Time Series Regression. *Biometrika* 75, 2, 335-346.
- Wei, W. W. S. (2006). *Time Series Analysis: Univariate and Multivariate Methods*, 2ªEd. Pearson Addison Wesley.

Anexo A – Figuras

Figura 1 - Gráfico do PIB de Macau, receitas do jogo e vendas a retalho




Figura 2 - Gráfico do PIB de Macau e despesas médias por visitante




Figura 3- Gráfico do PIB de Macau (GDPMO) às primeiras diferenças




Figura 4 - Gráfico das receitas de jogo (REVGAME) às primeiras diferenças




Figura 5 - Gráfico das vendas a retalho (RETSALE) às primeiras diferenças




Figura 6 - Gráfico das despesas médias por visitante (SPEVIS) às primeiras diferenças




Figura 7 – FAC e FACP da variável DLGDPMO

Date: 08/05/18 Time: 23:27
Sample: 2003Q1 2018Q1
Included observations: 60


























































Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.145	-0.145	1.3278	0.249
		2	-0.240	-0.266	5.0139	0.082
		3	-0.063	-0.160	5.2711	0.153
		4	0.552	0.500	25.478	0.000
		5	-0.143	-0.015	26.861	0.000
		6	-0.257	-0.122	31.412	0.000
		7	-0.132	-0.222	32.628	0.000
		8	0.411	0.067	44.686	0.000
		9	-0.072	0.059	45.066	0.000
		10	-0.196	0.046	47.937	0.000
		11	-0.126	-0.058	49.148	0.000
		12	0.335	0.006	57.822	0.000
		13	-0.035	-0.021	57.922	0.000
		14	-0.171	-0.019	60.290	0.000
		15	-0.077	0.048	60.777	0.000
		16	0.275	0.046	67.172	0.000
		17	-0.117	-0.157	68.363	0.000
		18	-0.131	-0.055	69.883	0.000
		19	-0.148	-0.176	71.873	0.000
		20	0.182	-0.069	74.970	0.000
		21	-0.088	-0.016	75.715	0.000
		22	-0.110	-0.025	76.891	0.000
		23	-0.096	-0.008	77.817	0.000
		24	0.348	0.268	90.344	0.000
		25	-0.019	0.133	90.381	0.000
		26	-0.114	-0.010	91.807	0.000
		27	-0.005	0.061	91.810	0.000
		28	0.255	-0.090	99.397	0.000

Figura 8 - Previsões para o PIB de Macau com os diferentes modelos em crescimento homólogo



Anexo B – Tabelas

Tabela A - Resultados dos diferentes testes de raiz unitária

Variável		GDPMO	REVGAME	SPEVIS	RETSALE
Termo determinístico		C	C	C	C
Augmented Dickey-Fuller	Em nível	0.409	0.317	0.412	0.621
	Em diferenças	0.040**	0.000***	0.010**	0.385
Phillips-Perron	Em nível	0.064*	0.371	0.048**	0.587
	Em diferenças	0.000***	0.000***	0.000***	0.000***
Kwiatkowski-Phillips-Schmidt-Shin	Em nível	0.863***	0.863***	0.779***	0.935***
	Em diferenças	0.369*	0.319	0.316	0.270

valor-p - *** (1%), ** (5%), * (10%)

Valores críticos do teste KPSS com constante: *** 0.739 (1%), ** 0.463 (5%), * 0.347 (10%)

Ao contrário dos testes ADF e PP, para o teste KPSS os valores na tabela correspondem a valores da estatística de teste

A hipótese nula do teste KPSS corresponde à estacionariedade, oposto ao teste ADF e PP

Tabela B - Critérios de seleção dos defasamentos do modelo VAR

p	LR	AIC	SC	HQ
1	-	-11,082	-10.508*	-10,859
2	53,477	-11,612	-10,465	-11.166*
3	22,331	-11,547	-9,826	-10,878
4	41.874*	-12.007*	-9,713	-11,115

Tabela C - Valores-p dos testes LM de autocorrelação

h	VAR(4)	VAR(1)
1	0.003***	0.002***
2	0,013**	0.003***
3	0.044**	0.000***
4	0.227	0.000***

valor-p - *** (1%), ** (5%), * (10%)

h - número de defasamentos incluídos na regressão auxiliar

Tabela D – Valores-p do teste de Jarque-Bera do modelo VAR(4)

Variável	Assimetria	Kurtose	Jarque-Bera
REVGAME	0.376	0.385	0.463
SPEVIS	0.121	0.676	0.275
RETSALE	0.674	0.549	0.765
GDPMO	0.215	0.189	0.196
Todas as variáveis	0.297	0.556	0.442

Tabela E – Valores-p do teste do valor próprio máximo de Johansen

r	VAR (1)	VAR(4)
0	0.009***	0.259
1	0.098*	0.472
2	0.359	0.558
3	0.181	0.581
valor-p - *** (1%), ** (5%), * (10%)		

Tabela F- Valores-p do teste do traço de Johansen

r	VAR (1)	VAR(4)
0	0.001***	0.182
1	0.041**	0.412
2	0.181	0.550
3	0.181	0.581
valor-p - *** (1%), ** (5%), * (10%)		

Tabela G – Valor-p do teste do traço de Johansen com quebras de estrutura

r	Valor-p
0	0.000***
1	0.006***
2	0.559
3	0.761

*** (1%), ** (5%), * (10%)

Tabela H - Valores-p do teste de Wald/ Causalidade de Granger

Variáveis Dependentes	Variáveis Independentes				
	REVGAME	RETSALE	SPEVIS	GDPMO	Conjunta
REVGAME	-	0.007***	0.006***	0.446	0.001***
RETSALE	0.046**	-	0.982	0.347	0.007***
SPEVIS	0.021**	0.106	-	0.002***	0.001***
GDPMO	0.001***	0.829	0.684	-	0.001***

valor-p - *** (1%), ** (5%), * (10%)

Tabela I - *Output* da estimação do modelo ADL após procedimento GTS

Variável	Coefficiente	Estatística-t	Valor-p
Constante	1.724	3.056	0.004***
LGDPMO(-1)	-0.262	-3.120	0.003***
DLGDPMO(-3)	-0.137	-2.227	0.031**
DLGDPMO(-4)	0.666	8.767	0.000***
LREVGAME(-1)	0.129	2.537	0.015**
LRETSALE(-1)	-0.010	-0.295	0.769
LSPEVIS(-1)	-0.006	-0.082	0.935
DLREVGAME	0.453	7.478	0.000***
DLREVGAME(-3)	0.172	2.327	0.025**
DLREVGAME(-4)	-0.268	-4.233	0.000***
DLRETSALE(-2)	-0.296	-2.608	0.045**
DLSPEVIS	0.161	2.143	0.038**
DLSPEVIS(-4)	-0.167	-2.479	0.017**

valor-p - *** (1%), ** (5%), * (10%)

Tabela J - Resultados dos critérios de comparação para o período 2015-2018

Método	Critério	VEC	ADL	Holt Winters	ARIMA
Dinâmica	REQM	0.070836	0.046094	0.111285	0.062343
	EAM	0.062262	0.036513	0.092900	0.053909
	EAMP	0.541525	0.319287	0.808449	0.470109
Estática	REQM	0.029369	0.014313	0.104706	0.048485
	EAM	0.023785	0.011548	0.084548	0.037380
	EAMP	0.207728	0.100724	0.738590	0.326574

Tabela K - Resultados dos critérios de comparação para o período 2016-2018

Método	Critério	VEC	ADL	Holt Winters	ARIMA
Dinâmica	REQM	0.043186	0.023505	0.178429	0.047717
	EAM	0.035707	0.017111	0.159548	0.039355
	EAMP	0.311099	0.149404	1.387338	0.343373
Estática	REQM	0.032750	0.014530	0.038173	0.042192
	EAM	0.026480	0.011989	0.027882	0.031034
	EAMP	0.231302	0.104505	0.243335	0.271061

Tabela L - Resultados dos critérios de comparação para o período 2017-2018

Método	Critério	VEC	ADL	Holt Winters	ARIMA
Dinâmica	REQM	0.039119	0.015635	0.018291	0.018995
	EAM	0.029800	0.012952	0.015669	0.015110
	EAMP	0.258408	0.112337	0.136287	0.131036
Estática	REQM	0.026649	0.017821	0.021304	0.018951
	EAM	0.020533	0.015341	0.017869	0.015010
	EAMP	0.178274	0.133496	0.154978	0.130173

Tabela M - Resultados do teste Diebold-Mariano com previsões dinâmicas

Teste	VEC - ADL	HW - ADL	ARIMA - ADL	ARIMA-VEC	ARIMA-HW	VEC-HW
Diebold-Mariano	0.404	2.097	0.215	0.417	2.121	5.375
	0.6865	0.0360**	0.8301	0.6769	0.0339**	0.0000***
Diebold-Mariano (HLN)	0.831	4.315	0.441	0.858	4.367	11.061
	0.4184	0.0005***	0.6648	0.4038	0.0005***	0.0000***

valor-p - *** (1%), ** (5%), * (10%)

Tabela N - Resultados do teste Diebold-Mariano com previsões estáticas

Teste	VEC - ADL	HW - ADL	ARIMA - ADL	ARIMA-VEC	ARIMA-HW	VEC-HW
Diebold-Mariano	2.850 0.0044***	2.447 0.0144**	3.072 0.0021***	2.541 0.0111**	1.576 0.1151	1.908 0.0564*
Diebold-Mariano (HLN)	2.764 0.0138**	2.374 0.0305**	2.980 0.0088***	2.465 0.0254**	1.529 0.1458	1.851 0.08267*

valor-p - *** (1%), ** (5%), * (10%)

Tabela O - Previsões em valor absoluto para a variável do PIB

	Observado	ADL	VEC	ARIMA	Holt-Winters
1º T 2013	110847				
2º T 2013	113004				
3º T 2013	116330				
4º T 2013	131548				
1º T 2014	124291				
2º T 2014	119456				
3º T 2014	112039				
4º T 2014	110276				
1º T 2015	96010				
2º T 2015	90107				
3º T 2015	87619				
4º T 2015	91683				
1º T 2016	84668				
2º T 2016	85051				
3º T 2016	92707				
4º T 2016	99839				
1º T 2017	94383				
2º T 2017	94429				
3º T 2017	98530				
4º T 2017	107875				
1º T 2018	103062				
2º T 2018		102273	104660	103706	103212
3º T 2018		104489	107955	107792	107726
4º T 2018		112026	113675	116274	115955
1º T 2019		107122	108244	112910	106275

Tabela P - Previsões em variação homóloga para a variável do PIB

	Observado	ADL	VEC	ARIMA	Holt-Winters
1º T 2013	11,1%				
2º T 2013	9,4%				
3º T 2013	10,8%				
4º T 2013	13,3%				
1º T 2014	12,1%				
2º T 2014	5,7%				
3º T 2014	-3,7%				
4º T 2014	-16,2%				
1º T 2015	-22,8%				
2º T 2015	-24,6%				
3º T 2015	-21,8%				
4º T 2015	-16,9%				
1º T 2016	-11,8%				
2º T 2016	-5,6%				
3º T 2016	5,8%				
4º T 2016	8,9%				
1º T 2017	11,5%				
2º T 2017	11,0%				
3º T 2017	6,3%				
4º T 2017	8,0%				
1º T 2018	9,2%				
2º T 2018		8,3%	10,8%	9,8%	9,3%
3º T 2018		6,0%	9,6%	9,4%	9,3%
4º T 2018		3,8%	5,4%	7,8%	7,5%
1º T 2019		3,9%	5,0%	9,6%	3,1%